

EMG Tabanlı MYO Kol Bandı ile Parmak Hareketlerinin Müzikal Etkileşim Performansına Etkisinin Araştırılması

Eda ÇETİN¹, İlayda KAYA², Kübra ERAT^{3*}, Pınar ONAY DURDU⁴

Öz

Giyilebilir sensörler ve kamera tabanlı cihazlar gibi modern teknolojiler, temassız müzik performanslarına olanak tanıyan Müzikal İfade için Yeni Arayüzler (MİYA) kapsamında olan çeşitli jest tabanlı kontrolörlerin geliştirilmesini sağlamıştır. Bu çalışma, MYO kol bandının MİYA bağlamındaki performansına odaklanmakta, özellikle kullanıcıların piyano ile fiziksel temas olmadan EMG sinyalleri aracılığıyla basit piyano parçaları çalmalarını sağlamaktadır. Piyano çalma sırasında kullanıcıların kol kaslarından EMG verileri toplanmış ve sınıflandırma için makine öğrenimi algoritmaları (SVM - Destek Vektör Makineleri, GB - Gradyan Güçlendirme ve RF - Rastgele Orman) kullanılmıştır. Sonuçlar, EMG sinyallerinin ön işleme sonrası GB algoritmasının %97,40 ile en yüksek doğruluğu elde ettiğini göstermiştir. Çalışmada elde edilen bulgular, MYO kol bandı gibi EMG tabanlı teknolojilerin etkileşimli müzik yapma deneyimini geliştirebileceğini ve doğrudan müzik performansına olanak sağlayabileceğini göstermektedir.

Anahtar Kelimeler: EMG, MYO kol bandı, Müzikal ifade için yeni arayüzler (MİYA), Makine öğrenmesi, Doğal etkileşim.

Investigating the Impact of Finger Movements on Musical Interaction Performance Using an EMG-Based MYO Armband

Abstract

Modern technologies such as wearable sensors and camera-based devices have enabled the development of a variety of gesture-based controllers that fall within the scope of New Interfaces for Musical Expression (NIMEs), enabling non-contact musical performances. This study focuses on the performance of the MYO armband in the context of NIMEs, specifically enabling users to play simple piano pieces through EMG signals without physical contact with the piano. EMG data was collected from the users' arm muscles during piano playing and machine learning algorithms (SVM - Support Vector Machine, GB - Gradient Boosting and RF - Random Forest) were used for classification. The results demonstrated that after preprocessing the EMG signals, the GB algorithm achieved the highest accuracy of 97.40% for classification. The findings of the study suggest that EMG-based technologies such as the MYO armband can enhance the interactive music-making experience and enable direct music performance.

Keywords: EMG, MYO armband, New interfaces for musical expression (NIME), Machine learning, Natural interaction.

^{1,2,4}Kocaeli Üniversitesi, Mühendislik Fakültesi, Bilgisayar Mühendisliği Bölümü, Kocaeli, Türkiye, edacetin2001ebru@gmail.com qkayailayda@gmail.com pinar.onaydurdu@kocaeli.edu.tr

³Kocaeli Üniversitesi, Fen Bilimleri Enstitüsü, Bilgisayar Mühendisliği Bölümü, Kocaeli, Türkiye, kubra.erat@kocaeli.edu.tr

*Sorumlu Yazar/Corresponding Author

1. Giriş

İnsanlığın müzik alanına ilgisi milattan önceki yüzyıllara dayanmaktadır ve o dönemlerden itibaren müzik yapabilmek için çeşitli enstrümanlar icat etmişlerdir (URL-1). Günümüzde ise teknolojiadaki gelişmelerin de etkisiyle sanatçılar ve araştırmacılar, insanların bedensel hareketlerini müzik enstrümanlarının çalınmasında da kullanmaya ilgi duymaya başlamışlardır (Erdem ve ark., 2020). Yeni teknolojiler genellikle giyilebilir sensörler veya kamera tabanlı cihazlar ile nesnelerle fiziksel olarak etkileşime girmeden müzikal temassız performanslara olanak tanıyan jest tabanlı kontrol cihazlarının kullanılmasına olanak tanımaktadır. Bu cihazlar müzik alanında Dijital Müzik Enstrümanları (DME) (DMI- Digital Musical Instruments) (Miranda ve Wanderley, 2006) ya da Müzikal İfade için Yeni Arayüzler (MİYA) (NIME- New Interfaces for Musical Expression) (Jensenius ve Lyons, 2017) olarak nitelendirilmektedir. Bu konuda dikkate değer örnekler arasında Sanal Hava Gitarı (Karjalainen ve ark., 2006), Sanal Kayan Gitar (Pakarinen ve ark., 2008) ve kullanıcıların bir web kamerası önünde gitar çalmayı taklit etmelerine olanak tanıyan Google'ın Öğretilbilir Makinesi (URL-2) yer almaktadır.

Geleneksel bir enstrümanı çalarken, enstrümanın fiziksel sınırlarına uymak için kas gücü sarf etmek gerekir. Yüzyıllar süren tasarımın ardından, geleneksel enstrümanların yapısı, bazı genişletilmiş çalma teknikleri veya ek ekipman kullanımı dışında artık fazla yoruma açık değildir (Erdem ve ark., 2020). Buna ek olarak, her müzik aletinin çalma hareketleri insanlardaki biyolojik sinyalleri üreten kas hareketlerini içerdiğinden, MİYA'lar bu biyosinyalleri algılayabilecek teknolojilere dayalı olarak geliştirilebilir (Lee, 2017). Biyosinyallerin popüler örnekleri arasında beyinden alınan elektroensefalogram (EEG), deriden alınan galvanik deri tepkisi (GSR), kalpten alınan elektrokardiyogram (EKG) ve kastan ölçülen elektromiyogram (EMG) yer alır ve tüm bunlar arasında MİYA alanında EMG sinyallerinin yaygın olarak kullanılabildiği görülmektedir (Karolus ve ark., 2018; Donnarumma ve ark., 2013; Atau, 1993; Knapp ve Lusted, 1990).

EMG, kasların kasılması sırasında ortaya çıkan elektrik akımlarını ölçen biyomedikal bir sinyaldir (Reaz ve ark., 2006). Kullanıcının koluna EMG sensörleri takıldığında, bunlar eldeki ve parmaklardaki kasların nasıl hareket ettiğini algılayabilir (Kamen ve Kinesiology, 2004). EMG, sadece uzuvlarınızın nerede olduğunu takip etmekten ziyade; aynı zamanda bir şey yapmaya hazır olduğunuzda ve gerçekten yaptığınızda kaslarınızın nasıl çalıştığını da algılamayı sağlar (Tanaka ve Ortiz, 2017). Bununla birlikte gelişen teknoloji ile EMG sinyallerinden jest tanıma ve parmak ucu kuvvetine dayalı hassas hareket tanımanın birleştirilmesi bu alandaki önemli yeniliklerden biridir (Ni ve ark., 2024). Bu alandaki örneklerden biri olan EMG sensörleri ile müzik enstrümanlarının kontrolü kullanıcılarla doğrudan etkileşim kurma potansiyelini artırır ve aynı zamanda kullanıcı ile doğal bir etkileşim sağlanmasına da olanak sağlar.

MİYA'lar ile ilgili araştırmalar genellikle ya kavramsal bir fikre uygun bir cihazın üretilmesi ya da mevcut bir kontrolcünün bir MİYA bağlamında kullanımına odaklanmaktadır (Nymoen ve ark., 2015). Bu çalışmanın amacı, EMG tabanlı MYO kol bandı kullanılarak kısıtlı parmak hareketlerinin müzikal etkileşim performansı üzerindeki etkilerini araştırmaktır. MYO kol bandı kullanılarak kullanıcının fiziksel bir piyanoya temasta bulunması gerekmeden MYO kol bandından elde edilen EMG sinyalleri aracılığıyla basit piyano parçalarını çalmasına olanak sağlayacak bir arayüz oluşturulmuştur. Farklı teknikler kullanılarak EMG sinyallerinin parmak hareketlerinin doğruluğu ve müzikal performans üzerindeki katkısı değerlendirilmektedir. Bu bağlamda, çalışmanın hipotezi, EMG tabanlı MYO kol bandı ile elde edilen parmak hareketlerine dayalı EMG sinyallerinin, müzikal etkileşim performansını anlamlı bir şekilde iyileştirebileceğidir. Ayrıca parmak hareketlerinin hassasiyeti ve doğruluğu, müzikal performansın etkinliğinde önemli bir rol oynayabilir.

2. Alanyazın Araştırması

Bu bölümde çalışma kapsamında incelenen ve bu çalışmaya temel sağlayan EMG sinyalleri kullanılarak MİYA alanında gerçekleştirilmiş güncel araştırma örnekleri sunulmaktadır. Ayrıca EMG sinyalleri ile parmak hareketlerinin algılanmasına yönelik güncel çalışmalara da örnekler sunulmaktadır. İncelenen çalışmalardan bazılarında EMG sinyalleri özel sensörler ile elde edilirken bazılarında ise bu çalışmada olduğu gibi MYO kol bandı kullanılmıştır. Tablo 1 ile de çalışmaların bağlamı, kullanılan sensör bilgisi, sinyal türü, sinyal işleme yöntemi ve sonuçlarına dayalı olarak özetlenmektedir.

(Putro ve ark., 2024) çalışmada parmak eklem açılarının tahmini için, ham sinyallerin hesaplama maliyetini düşürmeyi hedefleyen öznitelik çıkarımı ve transformer tabanlı derin öğrenme yöntemlerini birleştiren yeni bir yöntem önerilmiştir. Bu yöntem, parmak eklemi açılarının fleksiyon-ekstansiyonunu tahmin etmek için bileşenler arasındaki korelasyonu öğrenmek amacıyla transformer modelini kullanmaktadır. Çalışmada, NinaPro DB5 veri setinin üçüncü deneyi kullanılmıştır. Pencereleme süreci, öznitelik çıkarımı, yürütme süresi ve sonuçları önceki çalışmalarla karşılaştırmış ve sonuçlar, önerilen modelin Median Frekans öznitelik çıkarma yöntemi sayesinde önceki çalışmadaki 0,957 olan R-Kare skorunu 0,970'e çıkardığını göstermiştir.

(Rahman ve Nasor, 2024), EMG sinyallerinden parmak hareketlerinin makine öğrenmesi yöntemleriyle tahmin edildiği bir diğer çalışmada araştırmacılar, yedi farklı el hareketinden toplamda 6822 veri ile tahminleme yapmıştır. Çalışmada Myo kol bandında bulunan 8 adet EMG sensöründen alınan veriler kullanılmış olup, sinyaller öncelikle ön işleminden geçirilmiş daha sonra da on farklı öznitelik çıkarımı yapılmıştır. RBF çekirdek fonksiyonu kullanan SVM ile gerçekleştirilen sınıflandırmada yedi parmak hareketi için AUC %95,29 elde edildiği belirtilmiştir.

Brain-Body Digital Musical Instrument (BBDMI) projesi kapsamında araştırmacılar (Tanaka ve ark., 2023) insan vücudundan elde edilen fizyolojik sinyalleri kullanarak dijital bir müzik enstrümanı sistemini prototip olarak oluşturmayı amaçlamışlardır. Bu sistem içerisinde EMG sinyallerine ek olarak EEG sinyallerinin de birlikte kullanılması öngörülmüştür. Projede EEG ve EMG sinyallerinin elde edilmesi için Texas Instruments ADS129x çipini kullanan özel bir donanım prototipi olan EAVI ExG kullanılmıştır. OWL (Open Ware Laboratory) çerçevesi üzerinde gömülü sinyal işleme kullanılarak hem EEG hem de EMG sinyallerinin işlenmesi ve ses sentezi yapılması sağlanmıştır. Proje kapsamında kullanıcı çalışmaları ve deneyleri yapılarak, farklı müzisyenler ve kullanıcılarla EEG ve EMG sinyallerinin müzikal performanslarda nasıl kullanılabileceği ve etkileşimli sistemlerin nasıl geliştirilebileceği araştırılmıştır.

(Tepe ve Erdim, 2022) çalışmalarında EMG ve Jiyroskopik (GYRO) sinyalleri kullanarak parmak hareketlerinin sınıflandırdıkları çalışmada 5 farklı parmağa ait ve dinlenme pozisyonu olmak üzere toplam 6 adet harekete ait veri toplamıştır. Myo kol bandı aracılığıyla, on katılımcıdan 30 tekrarda kaydedilen veriler, SVM, K-En Yakın Komşu (KNN) ve Yapay Sinir Ağı (ANN) kullanılarak sınıflandırılmıştır. EMG ve GYRO sinyalleri ön işleme ve öznitelik çıkarımı işlemlerine tabii tutulmuştur. Sadece öznitelikler çıkarılmış EMG sinyalleri için en yüksek başarımlı ANN algoritması ile %94,40 elde edilmiştir. EMG ve GYRO sinyalleri için öznitelik çıkarılmış verilerle ise %96,30 ile yine en yüksek başarımlı ANN kullanıldığında tespit edildiği ve jiyroskopik sinyallerin sınıflandırma performansına artırıcı yönde etkisi olduğu raporlanmıştır.

(Mani ve Rao, 2021) MYO kol bandını kullanarak müzik aletlerinin öğrenim sürecindeki sürekli denetimi ve değerlendirmeyi sağlamak için parmak hareketlerini izlemeyi amaçlayan bir çalışma gerçekleştirmişlerdir. Elektronik klavye çalma bağlamında gerçekleştirdikleri sistem ile kullanıcıların parmak basımları, süreleri ve sıralamaları izlenmekte ve değerlendirilmektedir. Bu çalışmada, EMG sinyallerin işlenmesi için çeşitli yöntemler kullanılmıştır ve özellikle de sinyallerin sınıflandırılması amacıyla özellik ve algoritma seçimi üzerinde durulmuştur. Öznitelik seçimi için önceki çalışmalardan seçilen 11 öznitelikten oluşan bir öznitelik seti kullanılmıştır. Bu öznitelikler arasında zaman alanı parametreleri (RMS, RMS oranı, Frekans Enerjisi vb.) bulunmaktadır. Lineer Diskriminant Analizi (LDA – Linear Discriminant Analysis) kullanılarak boyut azaltma uygulanmış ve sonrasında sinyalleri sınıflandırmada RF sınıflandırıcısı kullanılmıştır. Seçilen öznitelik setinin ve sınıflandırma yaklaşımının performansı, çeşitli el hareketleri ve jestler içeren (Sapsanis, 2013; Sapsanis ve ark., 2013) tarafından yayınlanan çoklu kullanıcı ve tek kullanıcı iki farklı veri kümelerinde değerlendirilmiştir. Çalışmada, LDA ve RF kullanılarak önerilen özniteliklerden elde edilen doğruluk oranları sırasıyla %88,88 ve %79,86 olarak belirlenmiştir. Ayrıca LDA ve RF kombinasyonu diğer sınıflandırma yöntemleriyle örneğin SVM (%61,11) de karşılaştırılmıştır.

Sonuçta verilen uygulama için LDA ve RF kombinasyonunun daha iyi sonuçlar (%83,33) verdiği raporlanmaktadır.

(Kilian ve ark., 2021) piyanistlerin piyano çalarken notanın tonunu zenginleştirme ve daha duygusal, daha canlı bir ses sağlama amacıyla kullandıkları pitch vibrato efekti eklemelerine olanak tanıyan EMPiano sistemini geliştirmişlerdir. Geleneksel olarak bu efekt piyanoların kenarında bulunan bir pitch wheel veya benzeri bir kontrol mekanizması kullanılarak elde edilmektedir. EMPiano sisteminde EMG elektrotları aracılığıyla piyanistin istediği herhangi bir parmak veya el hareketinin tanınması sağlanarak otomatik olarak bu efektin çalma deneyimine entegre edilmesi sağlanabilmektedir. Çalışmada BrainVision LiveAmp EMG cihazı kullanılmaktadır. EMG sinyallerinin sınıflandırılması için ise SVM kullanılmıştır. Elde edilen bulgular, EMPiano'nun kullanıcıların piyano çalma deneyimini artırdığını ve kas aktivasyonlarına dayalı olarak hassas ve hızlı bir şekilde pitch vibrato efekti eklenebildiğini göstermektedir.

(Karolus ve ark., 2018) çalışmalarında EMG tabanlı EMGuitar adlı interaktif bir gitar eğitim sistemi tasarlamıştır. Bu sistem EMG ile elde edilen kas hareketlerine dayalı olarak gitar çalma doğruluğunu kontrol ederek geri bildirim sağlamakta ve tempo ayarlamaya yardımcı olmaktadır. Çalışmada EMG verilerini kaydetmek için hem EEG hem de EMG kaydetmede kullanılabilen BrainVision actiCHamp EEG kaydedicisi kullanılmıştır. EMG verileri katılımcılardan belirli bir akor dizisi çalmalarını içeren tekrarlamalarla elde edilmiştir. Elde edilen EMG sinyallerinin işlenmesi için öncelikle ön işleme adımları uygulanmıştır. Bu adımlar arasında sinyal segmentasyonu, bant geçiren filtre (2-100 Hz arasında) ve bant durduran filtre (49-51 Hz arasında) bulunmaktadır. Ayrıca sinyalin gürültüsünü azaltmak için bir dizi son-işleme adımı da kullanılmıştır. Sonrasında EMG sinyallerinden özellikler çıkarmak için kare ortalamalarının karekökü (RMS - Root Mean Square) özellikleri kullanılmıştır. Sınıflandırma işlemi için destek vektör makineleri (SVM – Support Vector Machine) kullanılmış ve EMG sinyalleri üzerinde çeşitli akorları tanımak için eğitilmiştir. Oturumlar-arası sınıflandırma performansı için F1 skoru 0,87, kişiye özel sınıflandırma performansı için F1 skoru 0,89 olarak raporlanmıştır. Geliştirilen eğitim sisteminin kullanılabilirliğine yönelik olarak katılımcılar, elektrotların gitar çalmalarına engel olmadığını ancak EMGuitar sisteminin çalma doğruluğu hakkında katılımcılara daha ayrıntılı geri bildirim sağlamasını belirtmişlerdir.

Benzer şekilde (Jensenius ve Lyons, 2017) MYO kol bandının MicroMyos adını verdikleri bir prototip müzik enstrümanın kontrolünde kullanımını değerlendirmişlerdir. Çalışma iki aşamada gerçekleştirilmiştir. İlk aşamada bireylerin mikro hareketlerini incelemek üzerine iki deney yapılarak farklı hareketlerin MYO kol bandı kullanılarak EMG ve ivmeölçer verileri toplanmıştır. Bu veriler ve deneyler sonucunda da MYO kol bandının dinlenme veya hafif kas hareketleri sırasında kas algılama yeteneğine odaklanılmıştır. Deneylerde elde edilen EMG sinyallerine önce bant geçiren filtreleme, sonrasında da tam dalga doğrultma uygulanmıştır. Toplanan EMG verileri, varyans analizi

(ANOVA) ve t-testleri gibi istatistiksel testler kullanılarak değerlendirilmiş ve farklı görevler sırasında kas aktivasyonu arasındaki farklar belirlenmiştir. İkinci aşamada kullanıcıların klasik enstrümanlardan farklı olarak daha az hareket olduğunda daha fazla ses çıkarmayı sağlayacak şekilde tasarlanan "MicroMyo" adlı bir prototip enstrümanı kullanmaları sağlanmıştır. Bu çalışma sonucunda kullanıcıların enstrümanı kolaylıkla herhangi bir kalibrasyona ihtiyaç duymadan kolaylıkla kullanabildikleri ve MYO kol bandının ses mikro etkileşimi için bir kontrol aracı olma potansiyeline sahip olduğu raporlanmıştır.

MYO kol bandının MİYA alanında uygulanmasına yönelik erken çalışmalardan birinde (Nymoen ve ark., 2015), MuMYO adlı bir prototip enstrümanın geliştirilmesi gerçekleştirilmiştir. Bu prototip arayüz ile de MYO cihazının müzikal bir kontrol cihazı olarak kullanım potansiyeli ve kullanılabilirliği değerlendirilmiştir. Çalışmada MYO cihazının tanımlı hareketleri beş farklı modda müzikal eylemleri gerçekleştirmek için kullanılmıştır. MYO kol bandının hareket ve kas sensör verilerinin müzikal üretim ve modifikasyon için kullanılabildiği, ancak dâhili sınıflandırma eylemlerinin sınırlı olduğunu raporlanmaktadır. Ayrıca kullanıcı çalışmasının sonuçları da MYO kol bandının kullanımının kullanıcılar arasında genellikle anlaşılabilir olduğu ve ilgi çekici bulunduğunu, ancak EMG sınıflandırıcısının zamanlama ve doğruluk sorunlarına sahip olduğunu göstermektedir.

(Tanaka ve Knapp, 2002), İnsan-Bilgisayar Etkileşimi (HCI - Human-Computer Interaction) ve çok modlu etkileşim araştırmalarının müzikal etkilerini inceledikleri çalışmalarında elektronik müzik cihazlarının kontrolü için bir model önermişlerdir. Geliştirdikleri sistemde kaslardaki elektriksel aktiviteyi elde etmede hem geleneksel elektrolit bazlı elektrotlar hem de aktif kuru EMG elektrotlar ile dönüş ve yer değiştirme verilerini elde etmede jiroskop sensörleri kullanılmaktadır. Bu iki veri türünün beraber kullanılmasıyla da daha zengin ve ifade edici bir kontrol arayüzü oluşturulması sağlanabilmiştir. Çalışmanın sonucunda, EMG ve göreceli pozisyon algılama (jiroskop sensör verileri) her ne kadar birbirlerinden bağımsız olarak çalışabilen iki ayrı sistem olarak kullanılabilirler de aslında her iki sistemin birbirini tamamladığı ve birlikte kullanıldıklarında daha etkili hale geldikleri vurgulanmaktadır.

Tablo 1. Alanyazın araştırmasında incelenen makaleler.


Çalışmanın Referansı	Bağlam	Veri Toplama Aracı	Sensör	Yöntem	Sonuç
(Putro ve ark., 2024)	EMG sinyallerinden parmak eklem açılarının tahmini	NinaPro DB 5 veri kümesi (Myo kol bandı)	EMG	Derin Öğrenme (transformer modeli)	Sonuçlar önerilen modelin R-Kare skorunun 0,970'e çıktığını göstermektedir.
(Rahman ve Nasor, 2024)	EMG sinyallerinden parmak hareketlerinin tahmini	Myo kol bandı	EMG	SVM	Önerilen SVM modeli, 7 parmak hareketi için AUC %95,29 değerine sahiptir.
(Tanaka ve ark., 2023)	EEG ve EMG sinyallerine dayalı Müzikal cihaz kontrolü	Texas Instruments ADS129x çipi, EAVI ExG	EEG, EMG	OWL (Open Ware Laboratory)	EEG ve EMG sinyallerinin müzikal performanslarda nasıl kullanılabileceği ve etkileşimli sistemlerin nasıl geliştirilebileceği araştırılmıştır.
(Tepe ve Erdim, 2022)	Parmak hareketlerinin EMG ve GYRO verileriyle sınıflandırılması	Myo kol bandı	EMG ve GYRO	SVM, KNN ve ANN	ANN ile sadece EMG sinyalleri için %94,40, EMG+GYRO için %96,30 başarımlar elde edilmiştir.
(Mani ve Rao, 2021)	Müzikal cihaz kontrolü	BrainVision LiveAmp	EMG	LDA, RF, SVM	Geliştirilen sistemin başarımları LDA ve RF için %83,33 ve SVM için %61,11 olarak raporlanmıştır.
(Kilian ve ark., 2021)	EMPiano	BrainVision LiveAmp	EMG	SVM	Geliştirilen EMPiano sisteminin piyano çalma deneyimini artırdığını vurgulanmıştır.
(Karolus ve ark., 2018)	EMGuitar- gitar eğitim sistemi	BrainVision actiCHamp	EMG	Segmentasyon, Bant geçiren filtre, Bant durduran filtre, RMS, SVM	Geliştirilen EMGuitar sisteminin oturumlar arası ve kişiye özel başarımları sırasıyla F1= 0,87 ve F1= 0,89 olarak raporlanmıştır.
(Jensenius ve Lyons, 2017)	MicroMyos Müzikal cihaz kontrolü	MYO kol bandı	EMG IMU	Bant geçiren filtre, Tam-dalga düzeltme, İstatistik yöntemler	MYO kol bandının ses mikro etkileşimi için bir kontrol aracı olma potansiyeline sahip olduğu raporlanmıştır

(Nymoen ve ark., 2015)	MuMYO Müzikal cihaz kontrolü	MYO kol bandı	EMG IMU	MYO kol bandının tanımlı hareketleri	MYO kol bandının dâhili sınıflandırmasının müzikal etkileşim için yetersiz olduğu raporlanmıştır.
(Tanaka ve Knapp, 2002)	Müzikal cihaz kontrolü	Elektrolit bazlı elektrotlar, aktif kuru EMG elektrotlar, ivmeölçer	EMG İvme verisi	-	EMG ve pozisyon algılamanın birlikte kullanılmasının daha etkili olduğu vurgulanmıştır.

3. Materyal ve Metot

3.1. Araştırma Tasarımı

Bu çalışma, Şekil 1’de sunulan çalışmanın genel akış şemasında da görüldüğü üzere belirli parmak hareketlerinin MYO kol bandı ile gerçek zamanlı algılanması ve bu verilerin önceden eğitilmiş bir model ile işlenmesi ve bunun sonucunda bir enstrümanın çalınması prensibine dayanmaktadır. Kol bandı aracılığıyla toplanan EMG sinyalleri, bir makine öğrenmesi algoritması ile gerçek zamanlı sınıflandırılır. Elde edilen bu sonuçlar, bir API aracılığıyla geliştirilen mobil uygulamaya iletilir ve bu sayede piyano çalma eylemi gerçekleştirilir. Bu sistem, kullanıcıların doğal parmak hareketleriyle mobil cihazlar üzerinden piyano çalabilmelerini imkân sağlar.



Şekil 1. Çalışmanın genel akışı.

3.2. MYO Kol Bandı

Thalmic Labs tarafından 2013 yılında geliştirilen MYO kol bandı, üzerinde bulunan EMG ve IMU sensörleri aracılığıyla bluetooth üzerinden veri kaydetmeyi sağlayan kablolu bir kol bandıdır (Düzenli ve ark., 2023). Şekil 2’de gösterilen MYO kol bandı ARM Cortex M4 adında kendine ait bir işlemcisi vardır. 8 kanaldan oluşan bu cihaz, 8 adet EMG sensörü ve 9 eksenli jiroskop, ivmeölçer, manyetometre sensörlerini içermektedir. LED ışıklar ve titreşimler aracılığıyla geri bildirim vermektedir. Kas aktivitesine ilişkin ölçülen ham EMG verileri, cihazın SDK’sı aracılığıyla 200 Hz örnekleme hızıyla toplanmaktadır.

Şekil 2’de görüldüğü üzere Myo kol bandı katılımcının sağ koluna yerleştirilmiştir. Cihazın takılma şekli ve doğru konumlandırılması verilerin doğru bir şekilde alınabilmesi için kritik bir faktördür. Cihazın konumu, dirseğin hemen altında, kolun ön yüz hizasında olacak şekilde ayarlanmıştır. Ayrıca, LED ışıklarının bulunduğu kanal, ön kol pozisyonuna getirilerek sinyal alımında doğruluk sağlanmıştır.



Şekil 2. MYO kol bandı ve yerleşim düzeni.

3.3. Veri Kümesi

EMG tabanlı hareket tanımda geliştirilmiş bireysel veri kümelerinde modeller önemli rol oynar. Ancak (Ni ve ark., 2024) çalışmasında da vurgulandığı gibi mevcut araştırmalar veri elde etme zorluğunu bir nebze azaltmak için hep aynı kişi üzerinde modellemeye odaklanmaktadır. Bu nedenle, bu çalışmada da benzer bir yaklaşım benimsenmiş ve kullanılan veri kümesi katılımcılar-arası performans farklılığının etkisinden kaçınmak için tek bir katılımcıdan birçok tekrarda toplanan sinyallerden oluşturularak kullanılmıştır.

Veri kümesi, tek elle çalınan müzik parçaları için beş farklı parmak hareketine (notaya) ait EMG verilerini içermektedir. Tablo 2’de, her bir parmak hareketinin karşılık geldiği nota ve etiketler ayrıntılı bir şekilde belirtilmiştir. Cihaz katılımcının sağ kolunda Şekil 2’de belirtildiği gibi konumlandırılarak, her parmak hareketinin Tablo 2’de gösterildiği gibi 3 saniye boyunca basılı tutularak (Mani ve Rao, 2021) EMG verisi kaydedilmiştir. Her bir parmak hareketi 50 tekrar gerçekleştirilmiş olup tekrarlar arası 5 saniye dinlenme süresi verilmiştir.

Tablo 2’de gösterilen bu parmak hareketleri, müzik enstrümanlarını çalmak için yaygın olarak kullanılan temel parmak pozisyonlarıdır. Katılımcıdan toplanan EMG verileri, bu parmak hareketlerinin her birini temsil eden etiketlerle (1: başparmak, 2: işaret parmak, 3: orta parmak, 4: yüzük parmak, 5: serçe parmak) eşleştirilmiştir.

Tablo 2. Gerçekleştirilen parmak hareketleri ve nota karşılıkları.

					
<i>Parmak</i>	Başparmak	İşaret Parmak	Orta Parmak	Yüzük Parmak	Serçe Parmak
<i>Nota</i>	SOL	LA	Sİ	DO	RE
<i>Etiket</i>	1	2	3	4	5

3.4. Sinyal İşleme

EMG sinyalleri deterministik olmayan bir sinyaldir, bu da EMG sinyalinin bir diferansiyel denklemle temsil edilemeyeceği anlamına gelir. Bu nedenle, EMG sinyali istatistiksel sinyal işleme teknikleri kullanılarak işlenmelidir (Kandemir, 2013). Dolayısıyla bu çalışmada oluşturulan veri kümesi, ön işleme ve öznitelik çıkarımı gibi işlemlere tabi tutulmuştur. Daha sonra veriler, sınıflandırma algoritmalarına gönderilerek sınıflandırılmaktadır.

3.4.1. Ön İşleme

EMG sinyallerinden oluşan veri kümeleri, laboratuvar ortamlarında toplandıklarında genellikle ideal olarak toplanır ve sinyal kaybı yaşanmayabilir ancak gerçek hayat uygulamalarında sinyaller çok kolay bozulabilir ve sinyal kayıpları yaşanabilir (Ni ve ark., 2024). Dolayısıyla EMG sensörlerine ait veriler, iç ve dış faktörlere karşı duyarlı olduğundan doğru bir şekilde yorumlanabilmesi için normalize edilmelidir (Chalard ve ark., 2020). Bununla birlikte MYO kol bandı Bluetooth bağlantılı

bir cihaz olduğu için bazı anlarda bağlantının kopması dolayısıyla eksik veri kayıtları olabilmektedir. Ön işleme aşamasında 8 farklı EMG sensöründen gelen veriler standardizasyon işlemine tabi tutularak, ortalaması 0 ve standart sapması 1 olacak şekilde standardize edilmiştir. Standardizasyon, her bir özelliğin ortalamadan arındırılması ve birim varyansa ölçeklenmesi yoluyla gerçekleştirilmiştir. Bu çalışma kapsamında, scikit-learn kütüphanesinin sunduğu StandardScaler yöntemi kullanılmıştır. StandardScaler (URL-3), özellikleri ortalamayı sıfırlayarak ve birim varyansa ölçekleyerek standartlaştırma işlemini etkili bir şekilde gerçekleştiren bir ön işleme tekniğidir. Bu işlem, Denklem (1)'de verilen matematiksel ifade ile tanımlanır:

$$X' = \frac{X - \mu}{\sigma} \quad (1)$$

Burada, X ham EMG sinyalinin, μ her sensör kanalının ortalama değerini, σ her sensör kanalının standart sapmasını ve son olarak X' standardize edilmiş EMG sinyalinin temsil etmektedir.

3.4.2. Kayan Pencere Yaklaşımı

Ön işlenmiş EMG sinyallerinden öznitelikler genellikle kayan pencere yaklaşımı ile hesaplanmaktadır (Khushaba vd., 2012). Bu çalışmada da sürekli ve zaman serisinden oluşan EMG sinyallerinden anlamlı verilerin elde edilebilmesi için kayan pencere yaklaşımı kullanılmıştır. Kayan pencere yaklaşımı, zaman serisi verilerini belirli uzunluktaki örtüşen veya ayrık pencerelere bölerek daha fazla örnek üretilmesini sağlar. Çalışmada her pencere bir saniyelik veri, yani 200 örnek içermektedir. Adım miktarı ise 50 (0,25 saniye) olarak belirlenmiştir. Yani %75 örtüşmeli pencerelerle sağlanmıştır. Kayan pencere yönteminde pencere sayısı Denklem (2)'de verilen formül (Khushaba vd., 2012) kullanılarak hesaplanmıştır.

$$\text{Eğitim kümesi örnek sayısı} = \frac{\text{veri uzunluğu} - \text{pencere boyutu}}{\text{adım miktarı}} + 1 \quad (2)$$

3.4.3. Öznitelik Çıkarımı

Ham sinyallerden gerekli bilgileri elde etmek için öznitelik çıkarma işlemine ihtiyaç vardır (Arozi ve ark, 2020). Öznitelik çıkarımı, EMG sinyallerinden yararlı bilgileri çıkarmak ve istenmeyen verileri ortadan kaldırmak için kullanılan bir yöntemdir (Boostani ve Moradi, 2003). Bu yöntem, ham sinyali analiz etmeyi ve sinyal işleme kullanarak jest içeriği hakkında önemli üst düzey bilgiler içeren bir temsil oluşturmaya imkân sağlamaktadır (Tamani ve ark., 2018). Özellikle EMG sinyalleri ile yapılan tanıma çalışmalarında, öznitelik çıkarma aşamasının uygulanmasının tanıma performansına önemli ölçüde etki ettiği bilinmektedir (Putro ve ark., 2024). Tablo 3'te bu çalışmada kullanılan

Ortalama Mutlak Değer (MAV – Mean Absolute Value), Varyans (VAR – Variance), Dalga Formu Uzunluğu (WL – Waveform Length) ve RMS özniteliklere ait kısa tanımlamalar ve matematiksel formülleri verilmiştir. Burada x_i sinyal örneklemini, N sinyalin uzunluğunu temsil etmektedir.

Bu çalışmada EMG sinyalinin ortalama genliğini ölçmek ve kas aktivitesinin genel seviyesini görmek için MAV, EMG sinyalinin genlik değişkenliğini ölçmek, sinyalin dalgalanma miktarını görmek ve kas kasılmalarının şiddetini belirlemek için VAR, EMG sinyalinin kompleksliğini, frekans bileşenlerini tespit etmek ve kas hareketinin karmaşıklığını ve hızını belirlemek için WL ve son olarak EMG sinyalinin enerjisini ve gücünü ölçmek ve motor ünitelerin aktivitesini belirlemek için RMS öznitelikleri seçilmiştir.

Tablo 3. Öznitelikler ve formülleri.

Öznitelik	Formül	Tanım
MAV	$\frac{1}{N} \sum_{i=1}^N x_i $	EMG sinyalleri üzerinden kas aktivitesini değerlendiren bir nitelik ve genellikle kasın genel aktivite düzeyini yansıtarak kasın ne kadar aktif olduğunu gösterir.
VAR	$\frac{1}{N-1} \sum_{i=1}^N x_i^2$	Bir veri kümesindeki değerlerin dağılımının ne kadar yaygın olduğunu ölçen bir istatistiksel özniteliktir. Varyans, verilerin ortalamadan ne kadar uzaklaştığını gösterir.
WL	$\sum_{i=1}^{N-1} x_{i+1} - x_i $	EMG dalga formunun zaman dilimi boyunca kümülatif uzunluğu olarak tanımlanabilir.
RMS	$\sqrt{\frac{1}{N} \sum_{i=1}^N x_i^2}$	Kasılma sırasında motor ünitelerdeki fizyolojik aktivitelerin seviyesi, kas kasılmasının bir göstergesi olarak sıkça kullanılan bir parametredir (Kandemir, 2013).

3.4.4. Sınıflandırma

Bu çalışmada Destek Vektör Makinesi (SVM), Gradyan Güçlendirme (GB) ve Rastgele Orman (RF) algoritmaları kullanılmıştır.

SVM, sınıflandırma ve regresyon problemlerinde kullanılan denetimli öğrenme temelli bir makine öğrenmesi algoritmasıdır. Farklı çekirdek türleri ile doğrusal ve doğrusal olmayan çeşitleri bulunmaktadır (Tepe ve Erdim, 2022). SVM'in temel amacı, sınıflar arasındaki en iyi ayrımı sağlayacak hiper-düzlemi bulmaktır. Bu çalışmada SVM algoritmasında rbf çekirdek fonksiyonu kullanılmıştır.

GB, bir dizi zayıf modeli ardışık olarak eğiterek güçlü bir model oluşturan bir topluluk öğrenme tekniğidir. Her bir model, bir öncekinin hatalarını düzeltmeye çalışır ve bu şekilde modelin doğruluğu artırılır (Friedman, 2001). GB, özellikle yüksek boyutlu ve karmaşık veri setlerinde etkili bir performans sergileyebilir (Chen ve Guestrin, 2016). Model, eğitim verileri üzerinden adım adım iyileştirilerek sınıflandırma doğruluğunu artırmayı hedefler (Natekin ve Knoll, 2013).

RF algoritması, yüksek derecede tahmin doğruluğu elde etmek için tahmin edicilerin ön-yükleme toplamasını ve rastgele hale getirilmesini kullanan bir regresyon ağacı tekniğidir (Rigatti, 2017). Birkaç rastgele karar ağacını birleştiren ve tahminlerini ortalama alarak, bir araya getiren yaklaşım değişken sayısının gözlem sayısından çok daha fazla olduğu ortamlarda iyi bir performans gösterebilmektedir (Biau ve Scornet, 2016).

3.4.5. Deneysel Çalışma Prosedürü

Gerçek zamanlı deneysel çalışmada, hazırlanan veri kümesi ile eğitilen model kullanılarak, MYO kol bandından anlık olarak alınan EMG verileri ile hareket tahminleri yapılır. Bu süreç aşağıdaki adımlardan oluşur:

Adım 1. Model Yükleme:

- Daha önce eğitilen model, tahmin işlemi için yüklenir.

Adım 2. Veri Toplama ve İşleme:

- MYO kol bandından gerçek zamanlı gelen EMG verileri belirli aralıklarla (her saniyede bir) toplanır.

- Toplanan veriler, uygun formatta bir veri çerçevesine dönüştürülür.
- Veriler, bir çift uçlu kuyruk veri yapısında tutulur. Bu yapı, maksimum 200 satır veri saklar ve 0.25 saniyede bir yeni veri geldikçe eski veriler kuyruk yapısından çıkarılır.

Adım 3. Veri Aktarma:

- Toplanan veriler, tahmin işlemi için modele aktarılır.
- Veri çerçevesine dönüştürülmüş EMG verileri, modelin öngörü yapabilmesi için sadece sensör değerlerini içerecek şekilde seçilir ve modele uygun formatta hazırlanır.

Adım 4. Sınıflandırma:

- Belirli aralıklarla saklanan EMG verilerinin model ile tahminlemesi yapılır.

Adım 5. Mobil Uygulamaya Aktarma

- Tahmin edilen hareket (nota), API aracılığıyla mobil uygulamaya aktarılır.
- Aktarılan harekete göre piyano ekranında ilgili notanın sesi çalınır.

3.4.6. Değerlendirme Metrikleri

Çalışma kapsamında performans ölçütü olarak karmaşıklık matrisinden elde edilen doğruluk, kesinlik, hassasiyet ve F1-Skoru kullanılmıştır (Powers, 2020). Burada, Doğru Pozitifler (TP) modelin pozitif olarak doğru tahmin ettiği örnekleri, Yanlış Pozitifler (FP) modelin pozitif olarak yanlış tahmin ettiği örnekleri, Doğru Negatifler (TN) modelin negatif olarak doğru tahmin ettiği, Yanlış Negatifler (FN) ise modelin negatif olarak yanlış tahmin ettiği sonuçları göstermektedir. Çalışmada EMG sinyalleriyle tahmin edilen parmak hareketlerinin toplam hareketler içindeki doğru tahmin oranını tespit etmek için Doğruluk, belirli bir parmak hareketi için modelin ürettiği pozitif tahminlerin ne kadarının gerçekten doğru olduğunu tespit etmek için Kesinlik, gerçekten meydana gelen bir parmak hareketinin model tarafından doğru şekilde tespit edilme oranını tespit etmek için Hassasiyet ve Kesinlik ve hassasiyetin dengeli bir ölçüsünü sunarak, modelin hem yanlış pozitifleri hem de yanlış negatifleri ne kadar iyi yönettiğini değerlendirmek için F1-Skoru hesaplanmıştır. Ayrıca Tablo 4'te çoklu sınıflandırma için Doğruluk, Kesinlik, Hassasiyet ve F1-Skor performans metriklerinin denklemleri verilmiştir.

Tablo 4. Doğruluk, Kesinlik, Hassasiyet ve F1-Skor metriklerinin denklemleri.

Metrik	Formül
Doğruluk	$\frac{\sum_{i=1}^k TP_i}{\sum_{i=1}^k (TP_i + FN_i + FP_i + TN_i)}$
Kesinlik (her bir i sınıfı için)	$\frac{TP_i}{TP_i + FP_i}$
Hassasiyet (her bir i sınıfı için)	$\frac{TP_i}{TP_i + FN_i}$
F1-Skor	$\frac{2 \times Kesinlik \times Hassasiyet}{Kesinlik + Hassasiyet}$


Performans değerlendirmesi için ayrıca ROC eğrisi kullanılmıştır. ROC eğrisi, bir modelin sınıflandırma performansını değerlendirmek için kullanılan önemli bir araçtır ve özellikle modelin çeşitli sınıflar üzerindeki ayırt edici gücünü gözlemlemek için kullanılır. Eğriler, her bir sınıf için ayrı ayrı çizilmiştir ve AUC (Area Under the Curve) değerleri belirtilmiştir. ROC eğrisi hesaplamasında "One-vs-All" (OvA) yöntemi kullanılmıştır. Bu yöntem, çok sınıflı sınıflandırma durumlarında ROC eğrisi ve AUC hesaplaması için sıkça kullanılan bir yaklaşımdır.

3.4.7. Yazılımlar

Bu bölümde veri toplama arayüzü ve uygulama arayüzünden bahsedilmiştir.

Veri Toplama Arayüzü:

MYO kol bandından alınan EMG sinyallerinin kaydedilmesi için geliştirilen Şekil 3'te örnek ekran görüntüsü gösterilen yazılım, Düzenli ve ark. (2023) çalışmalarında kullanılan veri toplama uygulaması örnek alınarak geliştirilmiştir. Bu yazılım, araştırmacıların veya geliştiricilerin EMG verilerini daha kolay bir şekilde toplamasını, belirli bir süre boyunca kaydetmesini ve bu verileri kullanıcının belirlediği bir dosyaya yazılmasını sağlar. Veri kaydı belirlenen süre boyunca yapılabildiği gibi manuel olarak da istenilen anda veri kaydı durdurulabilir.



Şekil 3. Veri kaydetme arayüzü.

Uygulama Arayüzü:

Proje kapsamında, uygulama Android Studio IDE'si kullanılarak Kotlin dilinde geliştirilmiştir. Android Studio, uygulama geliştirmek için resmi olarak kullanılan bir entegre geliştirme ortamıdır ve tüm Android cihazları için uygulama geliştirmeye olanak tanır.

Geliştirilen Android tabanlı enstrüman çalma uygulaması, MYO kol bandı kullanarak, kullanıcıya fiziksel bir piyano olmadan müzik çalma imkânı sunmaktadır. Özellikle hareket kısıtlı olan bireylerin ihtiyaçlarına odaklanan bu uygulama, aynı zamanda genel kullanıcı kitlesinin de rahatlıkla kullanabileceği bir arayüze sahiptir.


Şekil 4'te gösterilen uygulama, kullanıcıların "Başla" butonuna basmasıyla başlatılır. Kullanıcıdan başlangıçta tek elle ve çalışmaya dahil edilen 5 nota ile çalınabilen parça önerilerinden birini seçmesi istenir. Seçim yapıldıktan sonra piyano çalma arayüzüne geçilir. Kullanıcılar, seçtikleri parça için MYO kol bandı takılıyken parmak hareketleriyle, ekranda beliren numaraları takip ederek piyano çalma işlemini gerçekleştirirler. Uygulama, MYO kol bandını kullanarak kullanıcının parmak hareketlerini algılar ve bu hareketleri piyano notalarına dönüştürerek notalara uygun sesi çıkarır. Çalma işlemi tamamlandığında bitiş ekranı gösterilir ve kullanıcıya tamamlanma süresi bildirilir. Uygulama, hangi butona basıldığı bilgisini ve Python tarafından alınan anlık veri tahmin sonuçlarını API aracılığıyla uygulamaya ileterek işlevini sürdürür. API, Flask uygulaması tarafından JSON formatında bir yanıt döner ve bu yanıt, uygulama istemcisi tarafından kullanılır.




Şekil 4. Mobil piyano uygulama arayüzleri.

4. Deneysel Bulgular

Bu çalışmada, EMG sinyallerinden tahmin edilen parmak hareketlerine göre piyano çalma işlemi gerçekleştirilmiştir. Bu bağlamda EMG sinyallerinden parmak hareketlerinin tahmin edilip sınıflandırılması için öncelikle SVM, GB ve RF algoritmaları kullanılarak eğitim yapılmıştır. Model eğitim ve test aşamasında 8 adet EMG kanalında kaydedilen, her bir harekete ait EMG sinyalleri ve Tablo 2’de verilen etiketler kullanılmıştır. Veri kümesi rastgele bir biçimde %80 eğitim, %20 test kümesi olarak ayrılmıştır. Ayrıca 5-k çapraz doğrulama testi uygulanmıştır. Şekil 5’te örnek olarak baş parmak hareketi için EMG sinyallerinin sensör bazlı değişimi, Şekil 6’da ise her bir parmak hareketi için tüm sensörlerin değişim grafiği verilmiştir.



Şekil 5. Baş parmak hareketi için EMG sensör bazlı değişim grafikleri



Şekil 6. Her bir parmak hareketi için EMG sinyalleri değişim grafikleri.

Veri kümesi oluşturma aşamasında da belirtildiği üzere her bir parmak hareketi için 3 saniyelik EMG sinyali kaydedilmiş ve kullanılan Myo kol bandı saniyede 200 Hz örnekleme frekansına sahiptir. Her bir tekrar için elde edilen ham sinyal $[3 \text{ sn} \times 200 \text{ Hz}]$ olmak üzere 600 gözlem değeri içermektedir. Beş farklı parmak hareketinin her biri için 50 tekrar kaydedildiğinden, toplam gözlem değeri $[5 \text{ parmak hareketi} \times 50 \text{ tekrar} \times 600 \text{ gözlem}]$ olmak üzere 150.000'dir.

Kayan pencere yaklaşımı uygulanarak, her tekrarın 3 saniyelik sinyalinden %75 örtüşmeli, 200 örnek uzunluğunda pencereler çıkarılmış ve her bir tekrar için toplam 9 pencere üretilmiştir. Her bir

pencere için EMG sinyallerinden MAV, VAR, WL ve RMS olmak üzere dört temel öznitelik çıkarılmıştır. Bu işlem 8 EMG kanalı üzerinden gerçekleştirildiğinden, her pencere 32 boyutlu bir öznitelik vektörü ($[8 \text{ kanal} \times 4 \text{ öznitelik}] = 32$) ile temsil edilmiştir. Sonuç olarak, 50 tekrar için toplam pencere sayısı 2250 olmak üzere, 80:20 ayrılan eğitim ve test kümelerinin boyutu $[1800 \text{ gözlem} \times 32 \text{ öznitelik}]$ ve $[450 \text{ gözlem} \times 32 \text{ öznitelik}]$ 'dir. Ancak veri toplama esnasında bluetooth bağlantısındaki kopmalardan kaynaklanan veri kayıpları nedeniyle pencere sayısı dengeli hale getirmek için 1692:423 alınmıştır.



Tablo 5'te üç farklı algoritma ile gerçekleştirilen sınıflandırmanın doğruluk, kesinlik, hassasiyet ve F1-Skor sonuçları verilmiştir. SVM algoritması, eğitim ve test veri kümeleri arasında dengeli sonuçlar üretmiştir. Çapraz doğrulama sonucu elde edilen ortalama doğruluk değeri $\%95,33 \pm 1,07$ 'dir. Bununla birlikte eğitim doğruluğu $\%96,51$ iken, test doğruluğu $\%95,98$ olarak hesaplanmıştır. Benzer şekilde kesinlik, hassasiyet ve F1-skor değerleri de test kümesinde sırasıyla $\%95,99$, $\%95,88$ ve $\%96,52$ olup, modelin genelleme yeteneğinin yüksek olduğunu göstermektedir. GB algoritmasında ise çapraz doğrulama sonucu ortalama doğruluk değeri $\%95,39 \pm 0,44$ 'tür. Eğitim veri kümesinde tüm metriklerde $\%100$ başarı sağlamış, bu durum modelin eğitim verisine tam anlamıyla uyum sağladığını göstermektedir. Ancak test veri kümesinde doğruluk değeri $\%97,40$, diğer metrikler ise sırasıyla $\%97,43$, $\%97,28$ ve $\%97,35$ olarak hesaplandığı görülmektedir. RF algoritması ise çapraz doğrulama sonucu ortalama doğruluk değeri $\%93,5 \pm 0,94$ 'tür. Eğitim kümesinde $\%98,70$ doğruluk sağlarken, test kümesinde $\%94,80$ doğruluk oranına ulaşmıştır. Kesinlik, hassasiyet ve F1-skor gibi diğer metriklerde de benzer bir dağılım gözlenmiştir. Sonuç olarak, üç algoritma da EMG verileri üzerinde yüksek sınıflandırma performansı sergilemiş olup, en yüksek doğruluk oranı test kümesinde GB algoritmasına aittir. Bu nedenle gerçek zamanlı test esnasında tahminleme için GB algoritması kullanılmıştır.

Tablo 5. SVM, GB ve RF algoritmalarının ön işlenmiş EMG verileri için doğruluk, kesinlik, hassasiyet ve F1-Skor değerleri.

	SVM		GB		RF	
	Eğitim	Test	Eğitim	Test	Eğitim	Test
<i>Doğruluk</i>	0,9651	0,9598	1,0000	0,9740	0,9870	0,9480
<i>Kesinlik</i>	0,9652	0,9599	1,0000	0,9743	0,9873	0,9472
<i>Hassasiyet</i>	0,9653	0,9588	1,0000	0,9728	0,9869	0,9473
<i>F1-Skor</i>	0,9652	0,9591	1,0000	0,9735	0,9871	0,9470


Şekil 7-9'de yer alan grafikler, üç farklı algoritmaya ait karmaşıklık matrisileri verilmiştir. SVM modeli genel olarak yüksek doğruluk göstermiştir. Baş parmak sınıfında 87 doğru sınıflandırmaya karşılık 7 örnek hatalı sınıflandırılmıştır. En başarılı sınıf orta parmak olup $\%100$ 'e yakın bir

doğrulukla 84 örneğin tamamı doğru sınıflanmıştır. Serçe parmak sınıfında ise 3 örnek diğer sınıflara karışmıştır. Bu durum, özellikle baş parmak ve serçe parmak sınıfları arasında karışıklığın nispeten daha fazla olduğunu göstermektedir. GB modeli, tüm sınıflarda oldukça yüksek doğruluk oranları sağlamıştır. Genel olarak, sınıflar arasında ayırt edicilik sağlanmış ve karışıklık seviyesi oldukça düşürülmüştür. Bu durum, GB modelinin sınıflar arası sınırları etkili şekilde öğrenebildiğini göstermektedir. RF modeli de genel olarak tatmin edici sonuçlar vermiştir. Ancak SVM ve GB modellerine kıyasla, özellikle baş parmak sınıfında 5 örneğin işaret parmak ile karıştığı gözlenmiştir. Bu durum, RF modelinde özellikle komşu sınıflar arasında karar sınırlarının biraz daha belirsiz kaldığını göstermektedir.



Şekil 7. SVM algoritmasının karmaşıklık matrisi.


Şekil 8. GB algoritmasının karmaşıklık matrisi.




Şekil 9. RF algoritmasının karmaşıklık matrisi.

Şekil 10-12'de yer alan grafikler, üç farklı algoritmaya ait çok sınıflı ROC eğrilerini ve AUC değerlerini göstermektedir. SVM algoritması için AUC değerleri tüm parmak sınıflarında 1,00 olarak ölçülmüş, bu da modelin sınıflar arasındaki ayırım gücünün son derece yüksek olduğunu ortaya


koymuştur. GB algoritmasında ise baş parmak, işaret parmak, orta parmak ve serçe parmak sınıflarında AUC değeri 1,00 olarak gerçekleşmişken, yüzük parmak için AUC değeri 0,99 olarak ölçülmüştür. RF algoritması ise orta, yüzük ve serçe parmak sınıflarında 1,00 AUC değerine ulaşırken, baş ve işaret parmak sınıflarında AUC değeri 0,99 olarak kalmıştır. Bu grafikler karşılaştırıldığında, üç modelin de sınıflar arasında oldukça yüksek ayırt ediciliğe sahip olduğu gözlemlenmektedir.



Şekil 10. SVM algoritmasının ROC eğrileri.



Şekil 11. GB algoritmasının ROC eğrileri.



Şekil 12. RF algoritmasının ROC eğrileri.

Gerçek zamanlı test sürecinde, sinyallerin sınıflandırılmasında en yüksek doğruluk oranını sağlayan GB algoritması tercih edilmiştir. EMG sensörlerinden elde edilen sinyaller, 1 saniyelik veri içeren bir kuyruk yapısında toplanmış ve bu yapı her 0,25 saniyede bir güncellenerek %75 örtüşmeli pencereler ile sürekli tahminleme gerçekleştirilmiştir. Her bir saniye için karar anında, Chung ve Benalcázar (2019) çalışmasında kullanılan Mod yaklaşımı kullanılarak, tüm pencerelerde en sık tahmin edilen etiket, sinyale ait nihai sınıf etiketi olarak belirlenmiştir. Belirlenen etiket, sistemin çalışması planlanan müzik parçasındaki bir sonraki notanın etiket değeri ile eşleştiği durumda,

uygulama tarafından bu nota çalınarak kullanıcıya sesli geri bildirim sağlanmıştır. Öte yandan, tahmin edilen etiket ile hedef nota uyuşmadığında, sistem tahmin sürecine devam etmiş ve doğru tahmin gerçekleşene kadar sınıflandırma yinelemiştir. Bu süreç, ilgili müzik parçasındaki tüm notalar başarıyla tahmin edilene dek sürdürülmüştür. Gerçek zamanlı deneysel çalışmada, parmak hareketlerinin gerçek zamanlı tahmin sürelerinin API üzerinden uygulamaya aktarılması baş, orta, yüzük ve serçe parmak için bir saniyenin altında (0,25-1 sn) bir sürede gerçekleşse de işaret parmağı nispeten daha geç tahmin edilmiş ve bu süre 1-2,5 saniyeyi bulmuştur.

5. Tartışma ve Sonuç

EMG sinyalleri ile jest tabanlı uygulamalar, işaret dili tanıma, rehabilitasyon ve protez kontrolü gibi birçok alanda kullanılmaktadır (Ni ve ark., 2024). Özellikle jest tabanlı etkileşim, insan ile makineler arasında daha doğal etkileşime olanak sağlamaktadır. EMG sinyalleri aracılığıyla yapılan müzik enstrümanı kontrolü de bu doğal etkileşimin bir örneğidir. Literatürde çeşitli müzik enstrümanı (gitar (Karolus ve ark., 2018), piyano (Sapsanis ve ark., 2013)) ve uygulamalarının (Ni ve ark., 2024; Jensenius ve ark., 2017; Nymoen ve ark., 2015) EMG sinyalleri aracılığıyla kontrol edildiği çalışma bulunmaktadır.

Bu çalışmada, MİYA bağlamında kullanıcının fiziksel bir piyanoya temasta bulunması gerekmeden MYO kol bandından elde edilen EMG sinyalleri aracılığıyla ve kısıtlı parmak hareketleriyle basit piyano parçalarını çalmasına olanak sağlayacak bir arayüzün kontrolündeki performansına odaklanılmıştır. Bu amaçla öncelikle MYO kol bandı aracılığıyla elde edilen EMG sinyalleri kullanılarak bir veri kümesi oluşturulmuştur. Literatürde jest tanımda sıklıkla EMG sinyalleri (Fandaklı ve Okumuş, 2023) ve hareketlerin tanınmasında ise SVM (Rahman ve Nasor, 2024; Tepe ve Erdim, 2022; Karolus ve ark., 2018; Sapsanis, 2013; Tanaka ve Knapp, 2002), KNN (Tepe ve Erdim, 2022), ANN (Tepe ve Erdim, 2022), RF [Tanaka ve Knapp, 2002], LDA [Tanaka ve Knapp, 2002] ve derin öğrenme (Putro ve ark., 2024) modelleri kullanılmaktadır. Bu çalışmada da yüksek doğruluk önemli olduğu için literatürde EMG sınıflandırmasında yaygın olarak kullanılan sınıflandırma algoritmalarından SVM, GB ve RF algoritmaları kullanılmış ve sınıflandırma sonuçları kıyaslanmıştır. Ön işleme sonrası kullanılan algoritmalarından GB %97,40 ile en yüksek doğruluk değerine sahip olduğu görülmüştür. Çalışmada daha sonra hazırlanan veri kümesi ile eğitilen model kullanılarak, MYO kol bandından gerçek zamanlı olarak alınan EMG verileri ile hareket tahminleri yapılarak kullanıcının geliştirilen uygulama arayüzü üzerinden piyano parçalarını çalması sağlanmıştır.

Tablo 6, önerilen modelin literatürdeki diğer çalışmalarla karşılaştırılmasını sunmaktadır. Çalışmalar, farklı el ve parmak hareketlerini sınıflandırmak için çeşitli makine öğrenimi ve derin

öğrenme yöntemleri kullanmış olup, başarı oranları çevrimdışı ve gerçek zamanlı olarak değerlendirilmiştir. Önerilen modelde, 5 farklı parmak hareketini sınıflandırmak için GB algoritması ile diğer çalışmalarda (Rahman ve Nasor, 2024; Tepe ve Erdim, 2022) olduğu gibi yüksek doğruluk oranlarından birine ulaşmıştır. Gerçek zamanlı sınıflandırma da ise Zhang ve ark. (2019) çalışmasında ANN ile 5 farklı el hareketi için %98,7, Chung ve Benalcázar (2019) çalışmasında 5 farklı el hareketi ile $85,08 \pm 15,21$ gerçek zamanlı başarı sağlanmış olsa da Karolus ve ark. (2018) çalışmasında olduğu gibi bizim çalışmamızda da çevrimdışı performans yüksek olsa da gerçek zamanlı tahminde düşük kalmıştır. Gerçek zamanlı EMG sinyallerinin sınıflandırıldığı yüksek performanslı çalışmalarda (Chung ve Benalcázar, 2019; Zhang ve ark., 2019), genellikle Myo kol bandında ön tanımlı olan beş farklı el hareketi kullanılmıştır. Bizim ve gerçek zamanlı Karolus ve ark., (2018) çalışmasında ise gerçek hayatla uyumlu doğrudan bir enstrüman kullanımında ihtiyaç duyulan parmak hareketleri kullanılmıştır. Bu durum, Myo kol bandının hassas el ve parmak hareketlerini algılamadaki sınırlılıklarından kaynaklanıyor olabilir. Ayrıca, gerçek zamanlı tahminlerin 0,25 saniyede bir gerçekleştirilmesine rağmen, bağlantı kopmaları nedeniyle eksik veri alınması ya da tahmin sonuçlarının API aracılığıyla uygulamaya aktarılması sırasında yaşanan gecikmeler de performansı olumsuz etkileyebilmektedir. Buna karşın, çalışmamızda kullanılan modelin gerçek zamanlı tahmin süresi üzerinde yapılan iyileştirmeler, bu yaklaşımın ileri düzey gerçek zamanlı uygulamalarda kullanılabilirliğine yönelik önemli bir potansiyel taşıdığını ortaya koymaktadır.

Tablo 6. Önerilen modelin diğer modellerle karşılaştırılması.

Çalışma	Hareket	Yöntem	Çevrimdışı Başarım	Gerçek Zamanlı Başarım
(Rahman ve Nasor, 2024)	7 farklı parmak hareketi	SVM	AUC: %95,29	-
(Tepe ve Erdim, 2022)	6 farklı parmak hareketi	ANN	%94 (EMG)	-
(Chung ve Benalcázar, 2019)	5 farklı el hareketi	ANN	-	$85,08 \pm 15,21$
(Zhang ve ark., 2019)	5 farklı el hareketi	ANN	-	%98,7
(Karolus ve ark., 2018)	Sol el akor hareketleri	SVM	F1 Skoru: 0,59-0,89	F1 skoru: 0,10-0,46
Bizim çalışmamız	5 farklı parmak hareketi	GB	%97,40	-

Bu çalışma ile MYO kol bandı gibi EMG tabanlı teknolojilerin kullanıcıların müzik yapma deneyimini interaktif hale getirebileceği ve doğrudan müzikal performans sergilemelerine olanak tanıyabileceği ortaya konulmuştur (Jensenius ve Lyons, 2017; Nymoen ve ark., 2015). Ancak gerçek zamanlı tahminleme yapmada MYO kol bandının piyano çalma görevinde hassas parmak kas hareketlerin algılamada yetersiz kaldığı ve gecikmeler olduğu gözlemlenmiştir. Bunun çalışmaya dahil olan katılımcının fizyolojik yapısından kaynaklanabileceği düşünülmektedir. Myo kol bandı yerine (Aydoğan ve Aydın, 2023) çalışmasında olduğu gibi giyilebilir EMG sensörlerinin uygun konumlara yerleştirilerek parmak hareketlerinin daha hassas bir şekilde algılanması gerçek zamanlı deneysel çalışmalarda daha başarılı sonuçlar verebilir. Bunun yanı sıra yüksek kaliteli EMG sinyalleri için vücudun farklı bölgelerinde bulunan kaslardan sinyallerin alınması, eğitimin başarılı olmasına ve doğruluğun yüksek çıkmasına olanak sağlayabilir (Ni ve ark., 2024). Bununla birlikte sınıflandırma sonuçlarının uygulamaya aktarımı sırasındaki gecikmenin de minimize edilmesi, uygulamanın performansını arttıracaktır. Çalışmanın bir diğer kısıtı, sinyallerin gürültüden kolay etkilenme potansiyeline sahip olması ve gerçek ortamda sinyal kaybının kolay bir şekilde yaşanmasıdır (Ni ve ark., 2024). Bu da EMG sinyalleri aracılığıyla gerçek zamanlı enstrüman kontrolünü zorlaştırmaktadır. Gelecek çalışmalarda, öncelikle veri kümesi genişletilerek veri sayısı ve çeşitliliği artırılabilir. Kaydedilen EMG sinyallerine çeşitli gürültü giderme teknikleri (örneğin bant geçiren filtreleme, adaptif filtreleme) uygulanarak sinyal kalitesi artırılabilir ve böylece gerçek zamanlı testlerde daha yüksek doğruluk elde edilebilir. Ayrıca, cinsiyet, elektrot yerleşimi ve kas anatomisi gibi bireysel faktörler göz önünde bulundurularak katılımcı-bağımlı değerlendirmeler yapılabilir. Bu tür kişiye özel modeller, bireysel varyasyonları daha iyi öğrenerek, modelin performansı artırılabilir. Bununla birlikte EMG sensörleri içeren ve kolun farklı bölgelerine yerleştirilebilen sensörler kullanılarak daha kaliteli sinyal toplanabilir ve hassas parmak hareketlerinin daha iyi ve hızlı algılanması sağlanabilir, böylelikle gerçek hayata daha yakın gerçek zamanlı tahminleme gerçekleştirilebilir. Son olarak her iki kola yerleştirilen iki Myo kol bandı ile iki kol ve bilek hareketleriyle kontrol edilebilen farklı müzik enstrümanları (bateri, gitar vb.) üzerinde de gerçek zamanlı deneysel çalışmalar gerçekleştirilebilir.

Teşekkür

1919B012334786 proje nolu bu çalışma 2209-A Üniversite Öğrencileri Araştırma Projeleri Destekleme Programı kapsamında desteklenmiştir.

Yazarların Katkısı

Eda Çetin ve İlayda Kaya, tasarımın oluşturulması, literatür araştırması, deneylerin hazırlanması ve gerçekleştirilmesi, veri toplama, model oluşturma, mobil uygulamanın geliştirilmesi, sonuçların analiz edilmesi ve makale taslağının oluşturulması konularında katkı sunmuşlardır. Kübra Erat ve Pınar Onay Durdu, fikrin geliştirilmesi, tasarımın oluşturulması, deneylerin hazırlanması, literatür araştırması, kullanılan malzemelerin temini, yöntem tasarımı, eleştirel inceleme, yazım denetimi ve makalenin içerik açısından kontrol edilmesi konularında katkıda bulunmuşlardır.

Çıkar Çatışması Beyanı

Yazarlar arasında herhangi bir çıkar çatışması bulunmamaktadır.

Araştırma ve Yayın Etiği Beyanı

Bu makalenin yazarları çalışmalarında kullandıkları materyal ve yöntemlerin etik kurul izni ve/veya yasal-özel bir izin gerektirmediğini beyan ederler.

Kaynaklar

- Arozi, M., Ariyanto, M., Kristianto, A., and Setiawan, J. D. (2020). EMG signal processing of Myo armband sensor for prosthetic hand input using RMS and ANFIS. In *2020 7th International Conference on Information Technology, Computer, and Electrical Engineering (ICITACEE)* (pp. 36-40), Semarang, Indonesia, doi:10.1109/ICITACEE50144.2020.9239169.
- Atau, T., Musical technical issues in using interactive instrument technology with applications to the BioMuse. In *Proceedings of 1993 International Computer Music Conference, Tokio, Japan, 124–126, September 10-15*, pp. 124–126.
- Aydoğan, İ., and Aydın, E. A. (2023). Wearable Electromyogram Design for Finger Movements Based Real-Time Human-Machine Interfaces. *Politeknik Dergisi*, 26(2), 973-981, doi:10.2339/politeknik.1117947.
- Biau, G., and Scornet, E. (2016). A random forest guided tour. *Test*, 25(2), 197-227, doi:10.48550/arXiv.1511.05741
- Boostani, R., and Moradi, M. H. (2003). Evaluation of the forearm EMG signal features for the control of a prosthetic hand. *Physiological measurement*, IOP Publishing, 24(2), 309, doi:10.1088/0967-3334/24/2/307.
- Chalard, A., Belle, M., Montané, E., Marque, P., Amarantini, D., and Gasq, D. (2020). Impact of the EMG normalization method on muscle activation and the antagonist-agonist co-contraction index during active elbow extension: Practical implications for post-stroke subjects. *Journal of Electromyography and Kinesiology*, 51, 102403, doi:10.1016/j.jelekin.2020.102403.
- Chen, T., and Guestrin, C. (2016). XGBoost: A Scalable Tree Boosting System. *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining* (pp. 785-794), San Francisco, California, USA, doi:10.48550/arXiv.1603.02754.
- Chung, E. A., and Benalcázar, M. E. (2019). Real-time hand gesture recognition model using deep learning techniques and EMG signals. In *2019 27th European Signal Processing Conference (EUSIPCO)* (pp. 1-5), A Coruna, Spain, doi:10.23919/EUSIPCO.2019.8903136.
- Donnarumma, M., Caramiaux, B., and Tanaka, A. (2013). Muscular Interactions Combining EMG and MMG sensing for musical practice. In: *Proceedings of the International Conference on New Interfaces for Musical Expression* (pp. 1–4) Dajeon, Seoul, Korea, doi:10.5281/zenodo.1178504.

- Düzenli, M., Salur, K., Erat, K., and Durdu, P. O. (2023). Turkish Sign Language Recognition by Using Wearable MYO Armband. In: García Márquez, F.P., Jamil, A., Eken, S., Hameed, A.A. (eds), *International Conference on Computing, Intelligence and Data Analytics ICCIDA 2022* (pp. 344–357). Lecture Notes in Networks and Systems (Cham: Springer International Publishing), 643, Kocaeli, Turkey, doi:10.1007/978-3-031-27099-4_27.
- Erdem, C., Lan, Q., and Jensenius, A. R. (2020). Exploring relationships between effort, motion, and sound in new musical instruments. *Human Technology*, 16(3), 310-347, doi: 10.17011/ht/urn.202011256767.
- Fandaklı, S. A., and Okumuş, H. (2023). Comparison of artificial neural networks with other machine learning methods in foot movement classification. *Karadeniz Fen Bilimleri Dergisi*, 13(1), 153-171, doi:10.31466/kfbd.1214950.
- Friedman, J. H. (2001). Greedy function approximation: A gradient boosting machine. *Annals of statistics*, 1189-1232, doi:10.1214/aos/1013203451.
- Jensenius A. R., Gonzalez Sanchez V. E., Zelechowska, A., and Bjerkestrand, K. A. V. (2017). Exploring the Myo controller for sonic microinteraction, In *Proceedings of the International Conference on New Interfaces for Musical Expression* (pp. 442-445), Copenhagen, Denmark, doi: 10.5281/zenodo.1176308.
- Kamen, G., and Kinesiology, E. (2004). Research methods in biomechanics. *Human Kinetics Publ: Champaign*, IL, USA.
- Kandemir, G. (2013). *Design and implementation of a device to control a robotic arm by EMG signal*. Yüksek Lisans Tezi. Middle East Technical University, Ankara, Türkiye.
- Karjalainen, M., Mäki-Patola, T., Kanerva, A., & Huovilainen, A. (2006). Virtual air guitar. *Journal of the Audio Engineering Society*, 54(10), 964-980.
- Karolus, J., Schuff, H., Kosch, T., Wozniak, P. W., and Schmidt, A. (2018). EMGuitar: Assisting Guitar Playing with Electromyography. In *Proceedings of the 2018 Designing Interactive Systems Conference (DIS '18)* (pp. 651–655). Association for Computing Machinery, New York, NY, USA, doi:10.1145/3196709.3196803.
- Khushaba, R. N., Kodagoda, S., Takruri, M., & Dissanayake, G. (2012). Toward improved control of prosthetic fingers using surface electromyogram (EMG) signals. *Expert Systems with Applications*, 39(12), 10731-10738, doi:10.1016/j.eswa.2012.02.192.
- Kilian, A., Karolus, J., Kosch, T., Schmidt, A., and Woźniak, P. W. (2021). EMPiano: Electromyographic Pitch Control on the Piano Keyboard. *Extended Abstracts of the 2021 CHI Conference on Human Factors in Computing Systems* (pp.1-4), Yokohama, Japan, doi: 10.1145/3411763.3451556.
- Knapp, R. B., & Lusted, H. S. (1990). A bioelectric controller for computer music applications. *Computer music journal*, 14(1), 42-47, doi:10.2307/3680115.
- Lee D. E., (2017). *Electromyogram-based Interface for Musical Performance*. Yüksek Lisans Tezi, Ewha Womans University, Güney Kore.
- Mani, S., and Rao, M. (2021). Feasibility study of using myoband for learning electronic keyboard. In *2020 25th International Conference on Pattern Recognition (ICPR)* (pp. 10196-10202), Milan, Italy, doi: 10.1109/ICPR48806.2021.9412954.
- Miranda, E. R., and Wanderley, M. M. (2006). *New digital musical instruments: control and interaction beyond the keyboard*, Vol. 21. AR Editions, Inc.
- Natekin, A., and Knoll, A. (2013). Gradient boosting machines, a tutorial. *Frontiers in neurorobotics*, 7(21), doi:10.3389/fnbot.2013.00021.
- Ni, S., Al-qaness, M. A., Hawbani, A., Al-Alimi, D., Abd Elaziz, M., and Ewees, A. A. (2024). A survey on hand gesture recognition based on surface electromyography: Fundamentals, methods, applications, challenges and future trends. *Applied Soft Computing*, 112235, doi:10.1016/j.asoc.2024.112235.
- Nymoen, K., Haugen, M. R., and Jensenius, A. R. (2015). Mumyo—evaluating and exploring the myo armband for musical interaction. In *NIME 2015: Proceedings of the international conference on New Interfaces for Musical Expression* (pp. 215-218), Baton Rouge, LA, USA, doi: 10.5281/zenodo.1179150.
- Pakarinen, J., Puputti, T., and Välimäki, V. (2008). Virtual slide guitar. *Computer Music Journal*, 32(3), 42-54. JSTOR, doi:10.1162/comj.2008.32.3.42.
- Powers, D. M. W., (2020). Evaluation: From precision, recall and F-measure to ROC, informedness, markedness & correlation. *International Journal of Machine Learning Technology*. 2:1 (2011), 37-63, doi:10.48550/arXiv.2010.16061.
- Putro, N. A. S., Avian, C., Prakosa, S. W., Mahali, M. I., and Leu, J.-S. (2024). Estimating finger joint angles by surface EMG signal using feature extraction and transformer-based deep learning model. *Biomedical Signal Processing and Control*, 87, 105447, doi:10.1016/j.bspc.2023.105447.

- Rahman, K. M., and Nasor, K. M. (2024). Classification of Finger Movements Using Multi-channel EMG and Machine Learning. In: Kumar Jain, P., Nath Singh, Y., Gollapalli, R.P., Singh, S.P. (eds) *Advances in Signal Processing and Communication Engineering (ICASPACE 2023)* (pp. 439-451), Lecture Notes in Electrical Engineering, vol 1157. Springer, Singapore, doi:10.1007/978-981-97-0562-7_33.
- Reaz, M. B. I., Hussain, M. S., and Mohd-Yasin, F. (2006). Techniques of EMG signal analysis: Detection, processing, classification and applications. *Biological Procedures Online*, 8(1), 11-35, doi:10.1251/bpo115.
- Rigatti, S. J. (2017). Random forest. *Journal of Insurance Medicine*, 47(1), 31-39, doi:10.17849/inm-47-01-31-39.1.
- Sapsanis, C. (2013). *Recognition of basic hand movements using electromyography*. Yüksek Lisans Tezi. University of Patras, Greece.
- Sapsanis, C., Georgoulas, G., Tzes, A., and Lymberopoulos, D. (2013). Improving EMG based classification of basic hand movements using EMD. In *2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* (pp. 5754-5757), Osaka, Japan, doi:10.1109/EMBC.2013.6610858.
- Tamani, J. E., Cruz, J. C. B., Cruzada, J. R., Valenzuela, J., Chan, K. G., and Deja, J. A. (2018). Building Guitar Strum Models for an Interactive Air Guitar Prototype. In *Proceedings of the 4th International Conference on Human-Computer Interaction and User Experience in Indonesia, CHuXiD '18* (pp. 18-22), Yogyakarta, Indonesia, doi: 10.1145/3205946.3205972.
- Tanaka, A., and Knapp, R. B. (2002). Multimodal interaction in music using the electromyogram and relative position sensing. Paper presented at *International Conference on New Interfaces for Musical Expression (NIME)*, Dublin, Ireland.
- Tanaka, A., ve Ortiz, M. (2017). Gestural musical performance with physiological sensors, focusing on the electromyogram. In *The Routledge companion to embodied music interaction* (pp. 420-428). 1st Edition, Routledge, doi: 10.4324/9781315621364-46.
- Tanaka, A., Sèdes, A., Bonardi, A., Whitmarsh, S., Fierro, D., and Di Maggio, F. (2023). Brain-Body Digital Musical Instrument Work-in-Progress. In *ISEA 2023 - 28th International Symposium on Electronic Art, Le Cube Garges; Ecole Nationale Supérieure des Arts Décoratifs; Forum des Images*, Paris, France, doi:hal-04259596.
- Tepe, C., and Erdim, M. (2022). Classification of surface electromyography and gyroscopic signals of finger gestures acquired by Myo armband using machine learning methods. *Biomedical Signal Processing and Control*, 75, 103588, doi:10.1016/j.bspc.2022.103588.
- URL-1: <https://www.bbc.com/news/science-environment-18196349> (Erişim Tarihi: 14 Ağustos 2024).
- URL-2: <https://teachablemachine.withgoogle.com/> (Erişim Tarihi: 14 Ağustos 2024).
- URL-3: <https://scikit-learn.org/stable/modules/generated/sklearn.preprocessing.StandardScaler.html> (Erişim Tarihi: 10 Şubat 2025).
- Zhang, Z., Yang, K., Qian, J., & Zhang, L. (2019). Real-time surface EMG pattern recognition for hand gestures based on an artificial neural network. *Sensors*, 19(14), 3170, doi:10.3390/s19143170.